

# ANÁLISE DA INCERTEZA NA REPRESENTAÇÃO DE CLASSES DE COBERTURA DO SOLO URBANO RESULTANTES DA APLICAÇÃO DE UMA REDE NEURAL ARTIFICIAL

*Uncertainty analysis in the representation of the urban land cover classes through  
the application of artificial neural network*

LETÍCIA SABO BOSCHI<sup>1</sup>

MARIA DE LOURDES BUENO TRINDADE GALO<sup>2</sup>

Universidade Estadual Paulista

<sup>2</sup>Faculdade de Ciência e Tecnologia - Depto de Cartografia

<sup>1</sup>Programa de Pós-Graduação em Ciências Cartográficas

Rua Roberto Simonsen, 305 CEP 19060-900 Presidente Prudente, SP, Brasil

sabo@prudente.unesp.br, mlourdes@fct.unesp.br

## RESUMO

A diversidade de materiais nos ambientes urbanos determina uma estrutura de classes misturadas na classificação a partir de imagens multiespectrais. Nesse sentido, é importante definir um sistema de classificação utilizando um classificador não paramétrico, que permita incorporar dados de natureza não espectral, como os modelos de redes neurais artificiais. A partir dos valores de saída da rede, calculados em relação a cada classe, é possível analisar a incerteza associada a cada uma. Portanto, desenvolveu-se um experimento que utilizou a técnica de rede neural para a classificação da cobertura do solo urbano de Presidente Prudente e da análise da incerteza na representação das classes temáticas mapeadas. Os resultados mostraram que é possível discriminar as variações na cobertura do solo urbano através da aplicação de redes neurais artificiais e, a partir das representações geradas visualizar a variação espacial das incertezas na atribuição de classes, bem como, verificar que as classes apresentam ambigüidades em função da definição dos padrões de cobertura.

**Palavras-chave:** Classificação de ambientes urbanos, Redes Neurais Artificiais, Incerteza na classificação, Sensoriamento Remoto.

## ABSTRACT

The great diversity of materials that characterizes the urban environment determines a structure of mixed classes in a classification of multispectral images. In that sense, it is important to define an appropriate classification system using a non parametric classifier, that allows incorporating non spectral (such as texture) data to the process. They also allow analyzing the uncertainty associated to each class from the output values of the network calculated in relation to each class. Considering these properties, an experiment was carried out. This experiment consisted in the application of an Artificial Neural Network aiming at the classification of the urban land cover of Presidente Prudente and the analysis of the uncertainty in the representation of the mapped thematic classes. The results showed that it is possible to discriminate the variations in the urban land cover through the application of an Artificial Neural Network. It was also possible to visualize the spatial variation of the uncertainty in the attribution of classes of urban land cover from the generated representations. The class characterized by a defined pattern as intermediary related to the impermeability of the urban soil presented larger ambiguity degree and, therefore, larger mixture.

**Keywords:** Classification of urban environment, Artificial Neural Networks, Uncertainty in the classification, Remote Sensing.

## 1. INTRODUÇÃO

A classificação de dados de Sensoriamento Remoto é um processo de extração de informações que engloba um conjunto de técnicas que possibilitam reconhecer padrões e objetos com características similares nas imagens. O nível de detalhamento de dados é definido em um esquema de classificação, o qual deve considerar o uso que será dado à informação representada no mapa temático e os atributos das classes que são discerníveis nos dados disponíveis para sua elaboração. Segundo Congalton e Green (1999), um esquema de classificação tem dois componentes críticos: o conjunto de categorias ou rótulos definidos para representar as classes de interesse e o conjunto de definições ou regras que permitam caracterizar os diferentes tipos de ocorrências. Os mapas temáticos buscam generalizar as feições da superfície terrestre através das categorias especificadas no esquema de classificação.

O método de classificação adotado para a extração da informação de interesse é outro aspecto a ser considerado no esquema de classificação. Nesse sentido, as abordagens de classificação supervisionada usando redes neurais artificiais, têm apresentado resultados expressivos quando comparados aos métodos tradicionais de classificação de dados de Sensoriamento Remoto (VENTURIERI e SANTOS, 1998). Essa condição tem levado a uma crescente utilização dessa ferramenta, particularmente das redes multicamadas treinadas com o algoritmo de aprendizagem *backpropagation*. No entanto, apesar da quase unanimidade em relação ao modelo

de rede que tem sido adotado, diferentes situações de classificação exigem arquiteturas de rede e parâmetros de treinamento distintos, cuja definição influencia na capacidade da rede “aprender” as características das classes de interesse, que possibilitem uma associação correta para todo o conjunto de dados.

Genericamente, utilizar técnicas para classificar informações, colocando-as em grupos previamente definidos, implica em reduzir a entropia do sistema. A entropia, por sua vez é determinada pelo grau de incerteza contido em uma dada informação e é uma questão chave para avaliar a qualidade temática do mapa produzido e, conseqüentemente, verificar o grau de adequação para usos posteriores do conjunto de dados classificados (VAN DER WELL et al., 1998).

A questão da incerteza na atribuição de classes é particularmente significativa quando as classes definem um padrão misturado na cena. Pelo fato das cidades constituírem ambientes heterogêneos, sua classificação apresenta maior grau de dificuldade. Raramente, dentro de uma cidade, podem ser definidas classes discretas, pelo fato das diferentes categorias de ocupação do espaço urbano não apresentarem limites bem definidos, ou seja, transições abruptas. Dependendo da designação das classes, o que caracteriza esses ambientes urbanos é a ocorrência de classes misturadas, definindo uma continuidade nas áreas de transição entre elas (classes contínuas) (GALO, 2000b).

Em relação aos ambientes urbanos, Hamburger (1993) especifica que as categorias de uso do solo apresentam-se como uma manifestação entre o comportamento sócio-econômico e cultural e a ocupação espacial de uma determinada área. Por outro lado, as funções urbanas de residir, trabalhar, circular e recrear definem uma estrutura espacial bastante complexa, mesmo quando se trata de categorizar tipos de cobertura do solo urbano no contexto de uma análise específica, o que geralmente implica em se estabelecer classes com maior grau de ambigüidade.

Considerando que a classificação da paisagem urbana realizada a partir da utilização de imagens de média resolução espacial, incorpora uma componente de ambigüidade na definição das classes e, ainda, que os métodos estatísticos de classificação mais utilizados assumem uma função densidade de probabilidade conhecida para as classes, concebeu-se uma pesquisa que prevê o desenvolvimento de um sistema de classificação que não tenha essa limitação dos classificadores paramétricos e que, também, permita representar espacialmente a incerteza da classificação.

Nesse contexto, o objetivo deste trabalho é realizar uma análise da incerteza associada à representação de classes de cobertura do solo urbano, definidas a partir da aplicação de uma rede neural artificial para a classificação de uma imagem multiespectral de média resolução espacial e produzir representações que permitam visualizar a variação espacial da incerteza na atribuição das classes.

## 2. CLASSIFICAÇÃO E INCERTEZA

Segundo Gong (1996), classificação é um processo de abstração e generalização dos dados coletados sobre certo fenômeno. É um importante componente na análise de dados espaciais obtidos de diferentes fontes, envolvendo o agrupamento de medidas tomadas individualmente e a associação de cada grupo a uma categoria, de acordo com certas regras de similaridade.

Quando se trata da utilização da classificação em aplicações de sensoriamento remoto com a finalidade de realizar mapeamentos temáticos, deve-se prever, inicialmente, a definição de um sistema de classificação que seja adequado ao estudo que se pretende desenvolver. É importante estabelecer claramente as classes que constarão do mapeamento e, nesse processo, deve ser levado em consideração o nível de detalhamento oferecido pelos dados disponíveis.

Os mapas temáticos procuram generalizar as feições da superfície terrestre através de categorias especificadas em um projeto (esquema) de classificação apropriado para cada aplicação. Os esquemas de classificação constituem, então, os meios usados para organizar a informação espacial de maneira lógica e ordenada e possibilitam, para quem produz o mapa, caracterizar as feições da paisagem e, para o usuário do mapa, reconhecê-las (CONGALTON e GREEN, 1999).

Em sensoriamento remoto, a classificação de imagens consiste em se estabelecer um processo de decisão no qual um *pixel* ou grupo de *pixels* é definido como pertencente a uma determinada classe (VENTURIERI e SANTOS, 1998)

Para a análise de dados multiespectrais, Richards (1986) destaca dois procedimentos abrangentes de classificação. Um deles, definido como classificação não-supervisionada, é um meio pelo qual os *pixels* de uma imagem são associados a classes espectrais, sem que haja um conhecimento prévio da existência ou nome destas classes.

A classificação supervisionada se constitui na ferramenta analítica essencial usada na extração de informação quantitativa a partir de dados multiespectrais. O processo é dito supervisionado pois implica na interação entre o intérprete humano e o sistema de análise, possibilitando o treinamento do algoritmo de classificação através de amostras usadas para caracterizar ou estimar parâmetros estatísticos de cada classe. Um pressuposto importante adotado na maioria dos procedimentos mais consolidados de classificação supervisionada é o de que as classes de interesse podem ser modeladas por uma distribuição de probabilidade no espaço multiespectral e, conseqüentemente, descritas pelos parâmetros dessa distribuição.

Muitas vezes porém, as propriedades estatísticas de uma classe não podem ser estimadas, de modo que os problemas de teoria de decisão são melhor trabalhados pelos métodos que produzem diretamente as funções de decisão através dos dados de treinamento, sem levar em conta qualquer informação probabilística das classes de interesse. Os modelos de redes neurais artificiais permitem desenvolver adaptativamente os coeficientes das funções de decisão através de apresentações sucessivas de conjunto de padrões de treinamento (GONZALEZ e WOODS, 2000).


A tentativa inicial de reproduzir o alto desempenho do cérebro humano em tarefas cognitivas extremamente complexas motivou o desenvolvimento inicial dos modelos de Redes Neurais Artificiais (RNA). Tais modelos representam um tipo especial de processamento da informação que consiste de muitas células primitivas que trabalham em paralelo e estão conectadas através de ligações diretas. A principal função dessas células é distribuir padrões de ativação através de suas conexões, de maneira similar ao mecanismo básico do cérebro humano (ZELL et al., 1995).

As Redes Neurais Artificiais (RNA) são organizadas em camadas que compõem sua topologia ou arquitetura. Existem redes neurais de camada simples (*perceptron*) constituídas por um grupo de neurônios ou elementos de processamentos arranjados em apenas uma camada, e as redes multicamadas, formadas por várias camadas intermediárias ou pela combinação de várias redes de camadas simples (VENTURIERI e SANTOS, 1998). As camadas de elementos de processamento que compõem uma RNA têm suas próprias especificidades. A camada de entrada constitui uma estrutura de distribuição dos dados apresentados à rede; as camadas escondidas ou intermediárias realizam a maior parte do processamento, através das conexões ponderadas e podem ser consideradas como extratoras de características. Finalmente, na camada de saída, o resultado final é concluído e apresentado.

A topologia de uma rede refere-se à maneira como os elementos de processamento são organizados, o que afeta o desempenho da rede, uma vez que sua estrutura está intimamente ligada às regras de treinamento ou aprendizagem usadas na fase de treinamento da rede. Na Figura 1 é apresentada uma estrutura genérica para a configuração de uma RNA com uma camada escondida. Como pode ser observado, as interconexões entre cada nó tem um peso associado e quando um valor é transmitido a uma dada interconexão, ele é multiplicado pelo peso

Figura 1 – A estrutura de uma rede neural com uma camada escondida.

Fonte: Adaptado de Gonzales e Woods (1993).



A entrada de uma rede neural artificial é um conjunto de observações e as saídas são os valores associados às classes desejadas. O processo de obtenção dos pesos e tendências é feito através da aprendizagem da rede, que é, essencialmente, um treinamento supervisionado. Durante o treinamento, elementos do conjunto de observações que correspondem aos nós da camada de entrada são apresentados à rede vinculados à classe correspondente. Para uma dada entrada, a rede deve ajustar o conjunto de pesos associados às conexões e também aos limiares dos nós, de modo a se obter a saída desejada. Uma vez que esse ajustamento tenha sido efetuado pela rede, um outro par de entrada e saída desejada é apresentado e a rede calcula o valor de saída correspondente (GONG, 1996).

Normalmente, o algoritmo de treinamento ou aprendizagem utilizado para treinar uma rede *Multicamadas* é o *Backpropagation*, derivado da Regra Delta Generalizada (SCHALKOFF, 1992). Esse algoritmo permite um ajuste de pesos em cada uma das camadas e é projetado para minimizar o erro entre a saída calculada por uma arquitetura multicamadas e a saída desejada. O componente essencial desse algoritmo é o método iterativo que propaga regressivamente o erro requerido para adaptar os pesos, a partir dos neurônios da camada de saída para os nós das camadas precedentes (LIPPMANN, 1987).

De acordo com Gonzalez e Woods (1993) o número de elementos de processamento (nós) da camada de entrada corresponde ao número de variáveis que constituem o vetor de atributos dos dados a serem classificados, a camada de saída terá tantos elementos quantas forem as classes a serem mapeadas. A maior dificuldade está na definição do número de camadas escondidas e do número de nós que as compõem, o que tem sido resolvido experimentalmente e/ou pela experiência prévia do analista no domínio de uma dada aplicação.

Segundo Galo (2000a), após o aprendizado da rede, ela classifica os padrões de interesse usando o conjunto dos pesos ajustados durante a fase de treinamento e calculando, para cada padrão de entrada, os valores de saída (ou ativação de saída) associados a cada classe. Essas ativações de saída indicam então, o grau de associação de um dado padrão de interesse em relação a cada uma das classes, fornecendo um indicador importante da ocorrência de ambigüidade ou incerteza.

Normalmente, estimativas de probabilidade, geradas como subproduto da classificação, refletem as diferenças da incerteza para a classificação resultante e podem ser considerados indicativos de classificações duvidosas, de *pixels* misturados, classes heterogêneas, de limites ambíguos entre classes.

A incerteza introduzida na classificação de dados de Sensoriamento Remoto pode ser caracterizada pelos vetores de probabilidade que são gerados como um subproduto da classificação e disponibilizados na maioria dos procedimentos de classificação probabilísticos (GOODCHILD, SUN e YANG, 1992, apud GOODCHILD, 2002). Por exemplo, na classificação pela máxima probabilidade “a posteriori”, para cada *pixel* da imagem multiespectral é calculado um vetor de probabilidades o qual especifica a chance de uma dada classe se constituir na classe

verdadeira. Um dado *pixel* é entendido como uma variável aleatória  $x$  que pode estar associada a uma das classes  $\omega_i$ ,  $i = 1, \dots, M$ , então o vetor de probabilidade ( $\vec{x}$ ) calculado para este *pixel* especifica a probabilidade "a posteriori":

$$P(\omega_i / \vec{x}) \quad (01)$$

para  $i = 1, \dots, M$ , e onde  $\vec{x}$  denota o dado avaliado.

O conjunto das probabilidades indica a qualidade da classificação resultante em termos das incertezas envolvidas. Para explorar completamente a informação do vetor de probabilidade, medidas adicionais de incerteza são necessárias (VAN DER WEL et al., 1998).

A incerteza de um pixel em relação a uma dada classe é expressa pela probabilidade requerida para estabelecer esta classe com acurácia total. Assim, a incerteza ( $I$ ) na classe  $\omega_i$  é definida como:

$$I = 1 - P(\omega_i / \vec{x}) \quad (02)$$

para  $j = 1, \dots, M$ , e onde  $\vec{x}$  denota os dados avaliados.

Como a incerteza varia espacialmente, um mapa de incerteza é uma informação mais útil que uma quantificação global da incerteza, particularmente para um analista que usa o mapa para visualização exploratória ou confirmatória (MACHEACHREN, 1992). Nesse sentido, a representação da incerteza passa a ser uma estimativa, espacialmente distribuída, da qualidade da classificação.

Embora a exibição bivariada seja complexa e difícil de ser interpretada, provê uma imediata visualização da incerteza, representando uma importante regra na exploração e desenvolvimento de visualização da qualidade do dado, para a qual um número significativo de técnicas tem sido proposto e aplicado. As exibições bivariadas podem ser estáticas ou dinâmicas. Exemplos de técnicas estáticas são transformações de cor, mistura, foco, superfície de incerteza tridimensional e ofuscamento. Técnicas dinâmicas referem-se ao fatiamento, cintilamento, movimento e zoom (VAN DER WEL, 1998).

A incerteza é particularmente percebida nas zonas de transição entre classes, representando ambigüidade de posição e de atributo. Representação em cores/tons de cinza nas zonas misturadas pode destacar fronteiras entre tipos de vegetação ou de solo. Em uma aproximação, a incerteza pode ser representada pelo fatiamento dos valores de probabilidade. Nesse caso, diferentes valores de limiar podem ser atribuídos para diferenciar a qualidade dos dados.

### 3. ESTUDO DE CASO

O trabalho foi desenvolvido na área urbana e de expansão urbana de Presidente Prudente, Estado de São Paulo, definida com base na Carta de Zoneamento do Uso do Solo Urbano, a qual foi também utilizada para orientar a

aquisição dos dados de treinamento para a rede neural artificial e na delimitação e recorte da região de interesse.

A imagem multiespectral utilizada no experimento realizado foi obtida pelo sensor CCD do satélite Cbers2, cuja resolução espacial é de 20 metros, disponível nas bandas espectrais 1 (luz azul), 2 (luz verde), 3 (luz vermelha), 4 (luz infravermelho próximo). A data da tomada da cena foi 15 de dezembro de 2004, tendo sido obtida diretamente do *site* do INPE ([www.dpi.inpe.br/catalogo](http://www.dpi.inpe.br/catalogo)), que mantém um acervo das cenas já adquiridas, disponibilizando-as gratuitamente para *download*.

A utilização desta imagem de média resolução espacial para a extração da informação temática justifica-se pelo fato de que a saída da classificação deve permitir a estimativa da incerteza associada a cada *pixel*. Isso implica em se adotar uma abordagem de classificação *pixel a pixel*, considerando-se que o tamanho do *pixel* deve incorporar mistura de classes. Nesse contexto, quanto maior a resolução espacial, menor a ambigüidade.

A ferramenta computacional básica utilizada neste trabalho foi o simulador de redes neurais SNNS - *Stuttgart Neural Network Simulator*, desenvolvido por um grupo de pesquisadores da Universidade de Stuttgart. Porém nos processamentos prévios e representação dos resultados foram utilizados os aplicativos Spring (desenvolvido e disponibilizado gratuitamente pelo INPE) e Idrisi (desenvolvido originalmente na “Clark University”).

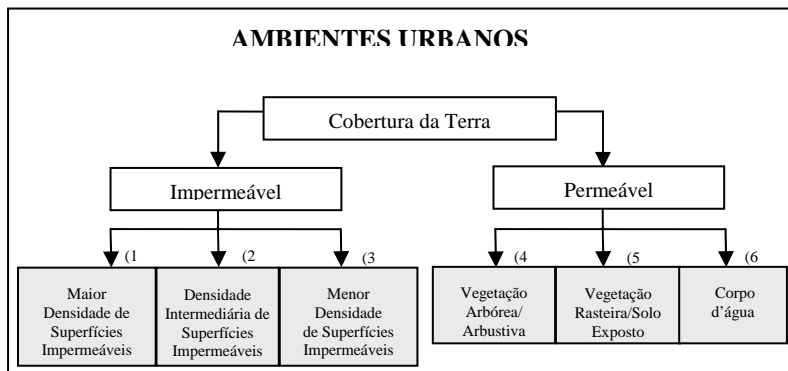
### 3.1 - Definição das classes de cobertura do solo urbano

A definição das classes baseou-se inicialmente na carta de zoneamento urbano e foi feita mediante a fusão dos tipos de uso que definiram um padrão de cobertura da terra similar na imagem multiespectral.

Porém, a especificação definitiva das classes considerou a estrutura hierárquica apresentada por Di Gregório (2004). O diagrama hierárquico concebido para essa análise é apresentado na Figura 2, enquanto que a descrição das classes e respectiva, designação na legenda do mapa temático, dos tipos de cobertura do solo da área urbana e expansão urbana é exemplificada no Quadro 1.



Figura 2 - Classes de cobertura do solo, especificadas para a área urbana e de expansão urbana. Fonte: Adaptado de Di Gregório (2004)



Quadro 1 - Caracterização das classes de cobertura do solo urbano.

<b>CLASSES</b>	<b>NÚMERO</b>	<b>DESCRIÇÃO</b>
Maior Densidade de Superfícies Impermeáveis	1	Constituída por áreas com maior densidade de construções, mais verticalizadas, ou simplesmente superfícies revestidas com material impermeável.
Densidade Intermediária de Superfícies Impermeáveis	2	Engloba áreas construídas, porém com maior heterogeneidade quanto aos revestimentos da superfície que se constituem de materiais permeáveis e impermeáveis.
Menor Densidade de Superfícies Impermeáveis	3	Áreas externas ao núcleo urbano, constituídas por bairros residenciais com terrenos de dimensões maiores, loteamentos recentes, etc, caracterizando construções mais esparsas.
Vegetação Arbórea/ Arbustiva	4	Refere-se às áreas verdes que ocorrem no contexto urbano e área de expansão urbana.
Vegetação Rasteira/Solo Exposto	5	Vegetação de menor porte, constituído basicamente por gramíneas.
Corpo d'água	6	

### 3.2 - Transformações aplicadas à imagem multiespectral

Para que os dados de sensoriamento remoto passassem a constituir os planos de entrada para a rede, que efetivamente permitissem a discriminação das classes de interesse foram aplicadas transformações específicas à imagem multiespectral. Desta maneira, foram realizados os seguintes processamentos: o registro entre a imagem multiespectral e a Carta de Zoneamento Urbano, uma transformação no espaço de cores (para converter as imagens do espaço RGB para o IHS e retorno para o espaço RGB) e a geração de duas imagens: uma representando variações de textura e outra realçando áreas de vegetação.

Para a conversão de composições coloridas das bandas multiespectrais (CCD/Cbers2) do modelo de representação RGB (*R-vermelho*, *G-verde*, *B-azul*) para as componentes IHS (*I-intensidade*, *H-matiz* e *S-saturação*), a componente I (*Intensidade*), que caracteriza o brilho total de uma cor, foi submetida a uma ampliação linear de contraste e essa componente contrastada foi usada na transformação inversa IHS – RGB. Desse modo, as componentes RGB passaram a apresentar uma variação similar no brilho. Das seis imagens resultantes da transformação, foram selecionadas aquelas que melhor definiram as feições de interesse: a componente G resultante da conversão usando originalmente a composição colorida das bandas 1, 2 e 3 e as componentes B e R, definidas a partir da composição das bandas 2, 3 e 4.

Uma imagem mostrando variabilidade ou textura foi obtida a partir da componente I (*Intensidade*), utilizando um operador de contexto denominado índice de fragmentação, o qual calcula um índice numérico com base na variabilidade espacial observada em uma janela de 3x3, 5x5 e 7x7 *pixels*. O objetivo da geração da imagem de textura é quantificar a variabilidade espacial a fim de possibilitar uma melhor caracterização dos padrões que definem as classes de interesse, visto a necessidade de se considerar também as propriedades estatísticas ou estruturais de uma vizinhança de *pixels*, ou seja, propriedades que possam descrever a variabilidade da cena.

Outra imagem que constituiu um plano de entrada da rede foi a de Índice de Vegetação, a qual é uma combinação aritmética simples baseada no contraste entre as respostas espectrais da vegetação na região do vermelho e do infravermelho próximo. O índice de vegetação utilizado foi o NDVI (*Normalized Difference Vegetation Index*), expresso como a diferença entre a banda do infravermelho próximo (IVP) e vermelho (VER), normalizada pela soma das bandas. O uso de uma imagem de índice de vegetação acarreta maior brilho nas áreas de vegetação e melhora a aparência da distribuição espacial de informações das imagens, tornando-as de fácil interpretação visual e computacional (SHIMABUKURO, 1991).

### 3.3 - Utilização da Rede Neural Artificial na classificação

A partir da análise do comportamento de uma RNA durante a fase de treinamento é possível avaliar sua adequação para a classificação dos dados disponíveis. Isto significa que, além da arquitetura da rede (definida pelo número de camadas escondidas e número de nós em cada camada), devem ser estabelecidos os parâmetros relacionados com as funções de aprendizagem e ativação e com as regras estabelecidas para a atualização de pesos e inicialização da rede, além do critério de término das iterações ou ciclos ou treinamento.

A definição de uma arquitetura de rede neural multicamadas, adequada para classificar o conjunto de dados de entrada, implicou na determinação prévia da dimensionalidade das classes de interesse e dos dados a serem classificados, os quais especificam, respectivamente, o número de elementos de processamento (nós) das camadas de saída e de entrada da rede. A configuração da rede neural artificial utilizada constou de cinco (5) elementos de processamento de entrada (três imagens selecionadas da transformação RGB-IHS-RGB; a imagem de textura e NDVI) e sete elementos de processamento na camada de saída (correspondentes às classes especificadas no Quadro 1, mais a parte externa à área de interesse – Fundo).

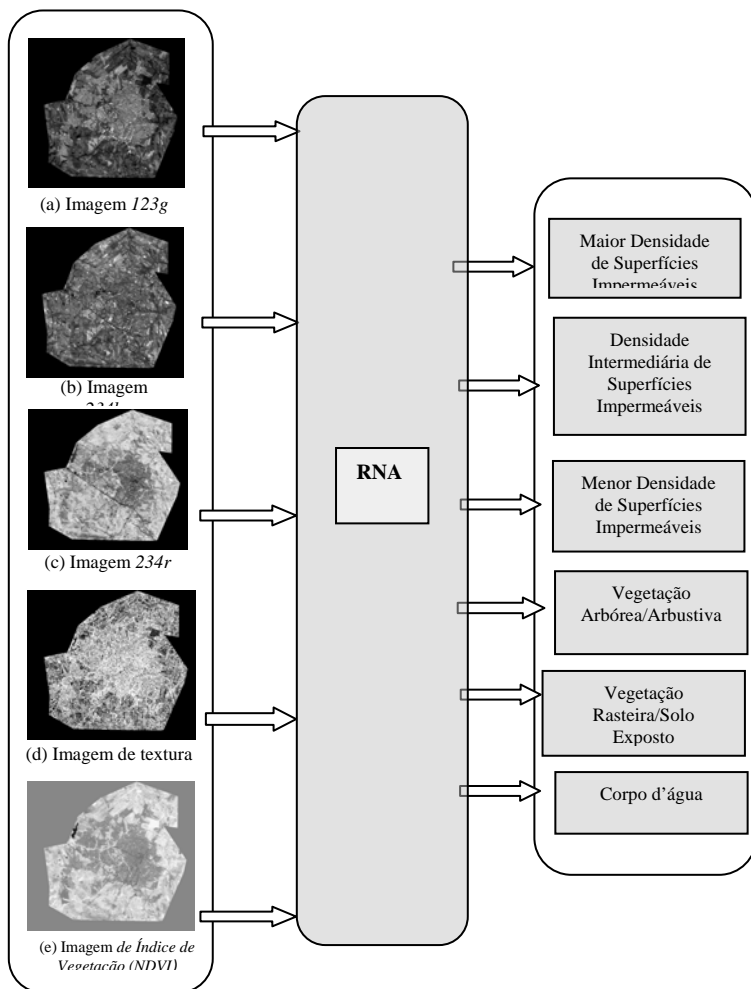
Para definir o número de camadas escondidas e o número de nós de cada uma dessas camadas foram realizadas simulações com diferentes arquiteturas de rede e verificado o desempenho da rede treinada para uma amostra de validação. O número de camadas escondidas e o número de elementos nestas camadas foram definidos experimentalmente, tendo sido avaliadas arquiteturas com uma e duas camadas escondidas.

Os pesos iniciais foram definidos no intervalo  $(-0,1 \text{ a } 0,1)$ , estabelecendo-se que a cada 100 iterações o treinamento seria interrompido para calcular o erro (EMQ) para o conjunto de validação. Esse erro foi monitorado tanto para padrões de treinamento quanto para validação verificando se o mesmo atingia o valor mínimo pré-estabelecido e fixado em 0,05.

Como o SNNS permite operar simultaneamente com dois conjuntos de padrões, um de treinamento e outro de validação, a maneira mais adequada para verificar a capacidade de generalização da rede foi monitorar a queda no erro médio quadrático (EMQ) para o conjunto de validação e finalizar o processo quando esse atingiria um valor mínimo (ZELL et al., 1995). Com base nesse erro e no resultado da aplicação da rede treinada à área estabelecida para validação, selecionou-se a arquitetura de rede mais adequada para classificar o conjunto de dados espaciais, constituindo-se de cinco elementos de processamento na entrada da rede, 54 nós na camada escondida e sete nós na camada de saída. Essa arquitetura, especificada como [5-54-7] foi treinada com 6000 iterações, já que com este ciclo de treinamento, a rede passou a discriminar todas as sete classes de interesse, com um erro igual a 0,00365.

A Figura 3, mostra o esquema de classificação por uma rede neural artificial, concebido para esta aplicação.

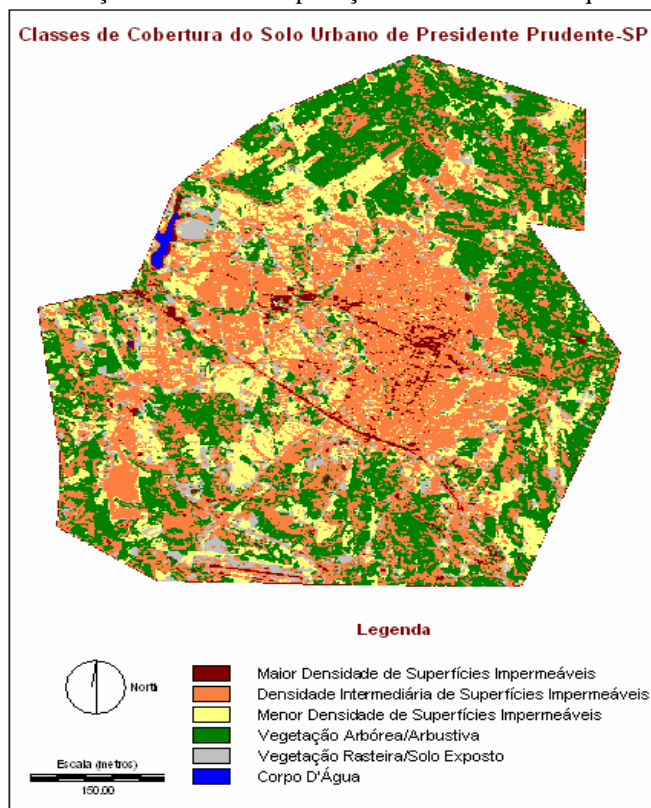
Figura 3 - Esquema de classificação pela rede neural artificial projetada.



Na Figura 4 apresenta-se a classificação resultante da aplicação da arquitetura [5-54-7], treinada com 6000 iterações. Como indicado na figura 4, a aplicação de uma arquitetura de RNA com uma única camada escondida possibilitou discriminar as seis classes de interesse, cuja delimitação geral no contexto da área urbana ficou

similar à configuração dos tipos de uso definidos na carta de zoneamento. Ainda notou-se que os eixos centrais da área urbana foram bem representados e incluídos na classe (1), caracterizada por áreas com maior densidade de construções e totalmente revestidas com material impermeável. A classe (2) apresentou maior mistura de classes, pelo fato de ser constituída por áreas construídas, porém com maior heterogeneidade quanto aos revestimentos da superfície. A classe (3) foi a que melhor representou o espalhamento urbano, conforme descrito no Quadro 1. Com base no padrão que apresentam na imagem e no conhecimento da região de estudos verificou-se que as classes (4) referente a áreas verdes que ocorrem no contexto urbano e na área de expansão urbana, (5) constituída por vegetação de menor porte e (6) corpo d'água foram representadas adequadamente na classificação.

Figura 4 - Classificação resultante da aplicação da RNA com a arquitetura [5-54-7]



### 3.4 - Tratamento dos dados de saída da RNA e representação da incerteza

Para dispor de uma estimativa da ambigüidade de cada *pixel* em relação a cada classe, os valores de ativação de saída da RNA, armazenados em um arquivo ASCII, foram tratados de modo a possibilitar a geração de mapas de incerteza por classe, através da estimativa das probabilidades por classe.

Para estimar a probabilidade ( $P_{ij}$ ) de cada *pixel*  $j$ , estar associado a uma dada classe  $i$ , utilizou-se a seguinte expressão:

$$P_{ij} = \frac{o_{ij}}{o_{1j} + o_{2j} + o_{3j} + o_{4j} + \dots + o_{ij}}$$

onde:

$o_{1j} \dots o_{ij}$  representam os valores de ativação de saída da RNA, referentes a um dado *pixel*  $j$ , para cada uma das classes  $i$ , sendo  $i = 1, 2, \dots, M$  e  $j = 1, 2, \dots, N$ .

Na sequência, foi avaliada a ambigüidade para cada *pixel*, a partir do cálculo da incerteza classe/*pixel* ( $I_{ij}$ ). Essa medida de incerteza resultou na aplicação da operação expressa na Equação (02), aplicada a cada *pixel*  $j$ , em relação à classe  $i$ :

$$I_{ij} = 1 - P_{ij}$$

Posteriormente, esses valores de incerteza por *pixel* foram tratados a fim de gerar as representações em tons de cinza por intervalos.

As Figuras 5, 6 e 7 referem-se à incerteza de cada *pixel* estar associado à determinada classe, ou seja, o complementar da probabilidade. Nestas figuras, as regiões que se apresentam mais claras indicam maior incerteza na associação à classe em questão. Já as áreas mais escuras representam menor incerteza. Quanto maior a incerteza, menor a chance de um *pixel* estar associado à determinada classe, de modo que regiões não incluídas na classe representada aparecem em branco.

Figura 5 - Imagens das classes (1) e (2), em tons de cinza representando a incerteza/classe

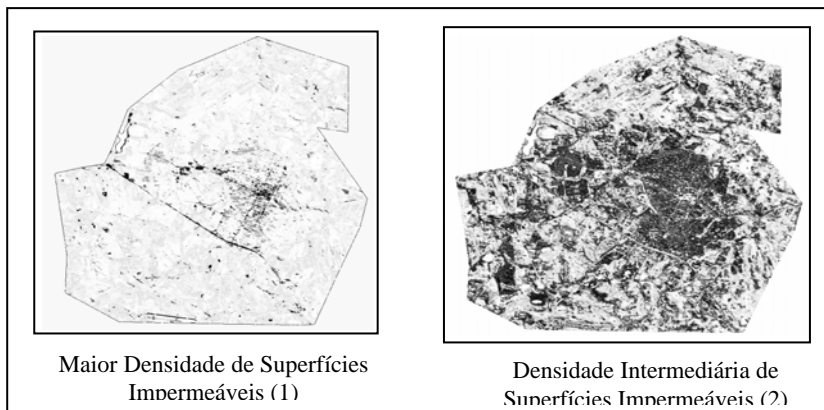


Figura 6 - Imagens das classes (3) e (4), em tons de cinza representando a incerteza/classe

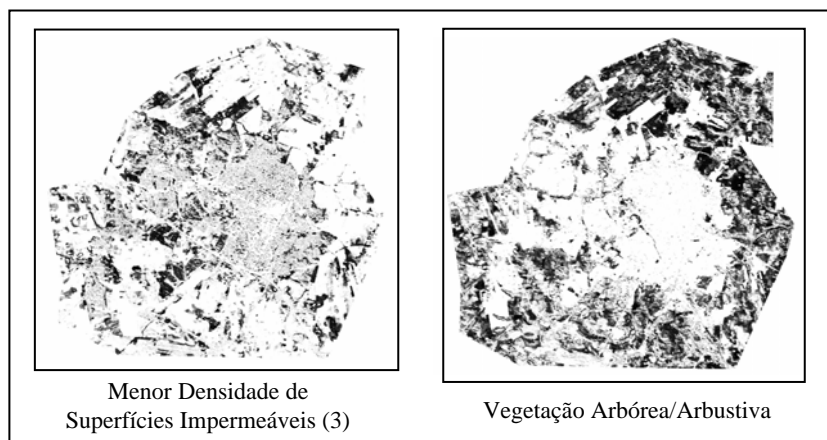



Figura 7 - Imagens das classes (5) e (6), em tons de cinza representando a incerteza/classe



Assim, na classe (1), as regiões caracterizadas pelas maiores incertezas são aquelas que não incluem os principais eixos urbanos centrais, enquanto na (2), as maiores ambigüidades estão concentradas na área externa ao núcleo urbano, inclusive no *Corpo d'água*. Na classe (3) as áreas mais confusas representam a

*Vegetação Arbórea/Arbustiva* e o *Corpo d'água*. Para a classe (4) as maiores incertezas ocorrem no núcleo urbano (inserção em outras classes), nas áreas de espalhamento de superfícies impermeabilizadas e no *Corpo d'água*. Já para a (5), poucos locais indicaram baixo grau de incerteza, enquanto que na (6) a única representação com ambigüidade reduzida refere-se a uma represa incluída na área de estudo.

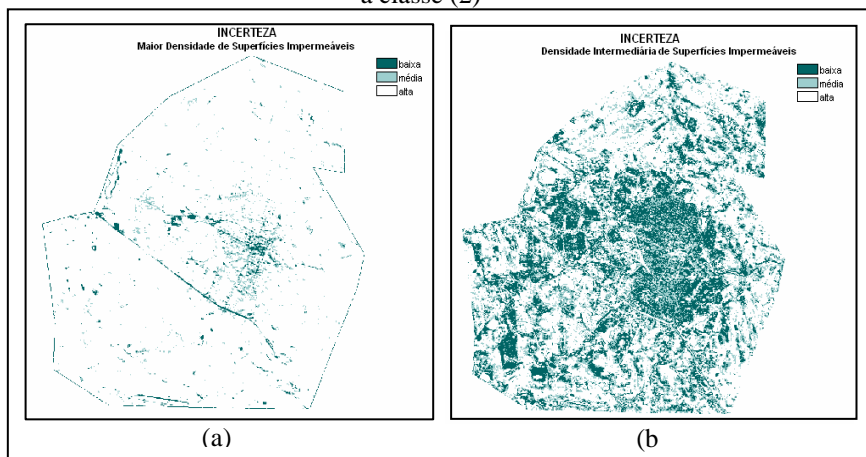
A partir das imagens de incerteza geradas para cada uma das seis classes foram elaborados mapas temáticos utilizando uma operação de fatiamento. As imagens foram fatiadas em três intervalos de incerteza, os quais estão associados à alta, média e baixa incerteza para cada uma das classes. Esses intervalos estão representados no Quadro 2.

Quadro 2 - Intervalos de valores que definiram o fatiamento das imagens de incerteza

Classes de Incerteza	Intervalos
Alta	0 - 85
Média	86 - 191
Baixa	192 - 255

A fim de permitir uma percepção das diferenças entre os mapas de estimativa de incerteza para cada classe, foram elaboradas as Figuras 8, 9 e 10. Nestes mapas temáticos é possível verificar as áreas associadas à alta, média e baixa incerteza em cada uma das seis classes. Os valores da alta incerteza são mostrados em branco, média incerteza em cinza e baixa incerteza em preto.

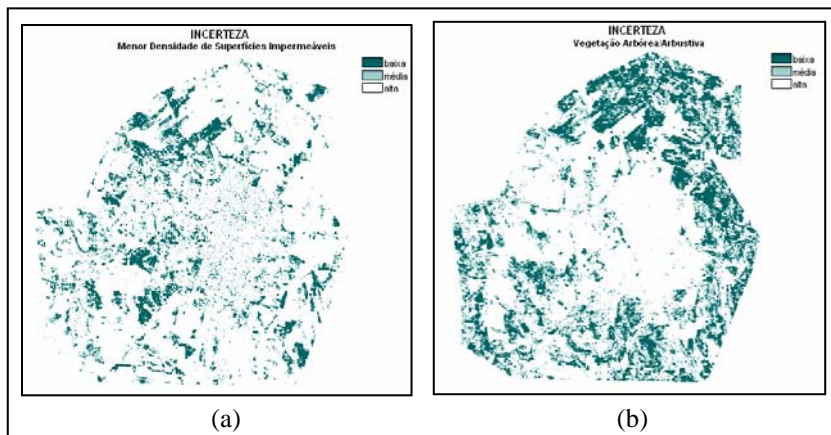
Figura 8 - (a) Mapa de incerteza representando a classe (1) e (b) representando a classe (2)





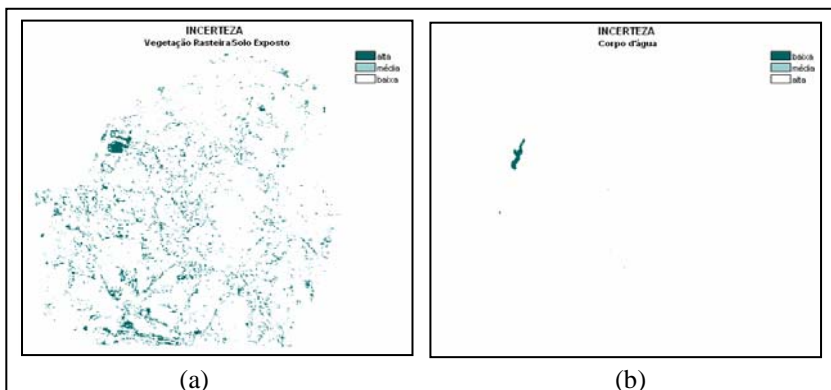
Na Figura 8 (a) é possível perceber que o núcleo central da cidade, altamente impermeabilizado, foi associado a um grau de incerteza pequeno, assim como, as principais avenidas e estradas pavimentadas. Porém, uma configuração rudimentar da área urbana pode ser percebida na incerteza (baixa) definida pela classe *Densidade Intermediária de Superfícies Impermeáveis* (Figura 8b).

Figura 9 - (a) Mapa de Incerteza da classe (3) e (b) da classe (4)



Os menores graus de incerteza ficaram definidos nas regiões da cidade que correspondem, principalmente, a loteamentos mais recentes localizados na periferia da mancha urbanizada os quais, de modo consistente, definiram a classe (3) mostrada na Figura 9a. Além disso, o entorno da mancha urbana apresentou alta correspondência com a classe (4), que resultou em incerteza baixa na Figura 9b.

Figura 10 - (a) Mapa de Incerteza da classe (5) e (b) da classe (6)



Na Figura 10 (a) menor ambigüidade está associada, principalmente a áreas contínuas de solo exposto, adequadamente vinculadas à classe *Vegetação Rasteira/Solo Exposto*. Entretanto, a representação mais consistente da incerteza pode ser claramente observada na Figura 10b, em relação à classe Corpo d'água, o qual apresentou reduzida ambigüidade em relação às demais classes e é, portanto, a única feição mostrada nesta figura.

#### 4. CONCLUSÕES

A aplicação de RNA na classificação e mapeamento da cobertura do solo urbano mostrou-se viável para a separação das classes de interesse, apesar de demandar um acréscimo de tempo de processamento na etapa de treinamento. A incorporação de dados de natureza não espectral (imagem de textura e imagem índice de vegetação (NDVI)) foi importante para a seleção das áreas de treinamento e também para a discriminação das classes, visto que a cobertura do solo urbano apresenta classes misturadas, definido assim uma continuidade nas áreas de transição entre elas (classes contínuas).

A partir dos valores de saída da rede, foram geradas informações quantitativas sobre a incerteza na representação das classes, o que possibilitou analisar a variação espacial da incerteza na atribuição de classes de cobertura do solo urbano. Nesta análise da incerteza foi possível perceber que as classes que apresentaram maior incerteza foram *Densidade Intermediária* e *Menor Densidade de Superfícies Impermeáveis*. O comportamento observado para essas classes já era esperado, conforme comentado anteriormente, visto que as médias estimadas a partir dos dados de treinamento tiveram pequena variação nos diferentes planos de entrada para classificação pela rede, antecipando maior dificuldade na discriminação entre elas.

Tendo em vista os resultados obtidos considera-se que as imagens orbitais de média resolução espacial constituem-se de uma fonte de dados útil para representar espacialmente e fornecer informações importantes para análises da área urbana para o nível hierárquico II, definido no esquema de classificação.

A realização do experimento confirmou a expectativa inicial quanto ao potencial da rede neural artificial em discriminar classes de cobertura do solo urbano, caracterizadas pelo alto grau de mistura que apresentam, e representar espacialmente a incerteza associada a cada classe, desde que a aplicação de interesse seja cuidadosamente modelada.

#### AGRADECIMENTOS

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq, pelo auxílio financeiro destinado a essa pesquisa sob a forma de uma bolsa de estudo. Ao Programa de Pós Graduação em Ciências Cartográficas (PPGCC) e ao Prof. Doutor Maurício Galo, docente do Departamento de Cartografia da FCT/UNESP, que desenvolveu e implementou os programas para converter os

dados a serem classificados em um arquivo padrão que pudesse ser compreendido pelo simulador, assim como, para a conversão dos valores de saída da rede neural artificial para o formato de uma imagem classificada.

## REFERÊNCIAS BIBLIOGRÁFICAS

- CONGALTON, R.G.; GREEN, K. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. 137p. Cap. 3, pg. 12-14. Boca Raton: Lewis Publishers, 1999.
- DI GREGORIO, A. *Land Cover Classification System (LCCS), version 2: Classification Concepts and User Manual*. FAO, Rome, 2004.
- GALO, M. L. B. T. *Aplicação de redes neurais artificiais na classificação de dados de sensoriamento remoto: Relatório de projeto de pesquisa referente ao triênio 29/07/97 a 28/07/00*. Presidente Prudente, FCT/Unesp, 2000.
- GONG, P.. Integrated Analysis of Spatial data from multiple sources: using evidential reasoning and artificial neural network techniques for geological mapping. *Photogrammetric Engineering & Remote Sensing*, v.62, n 5p, 513 – 523, 1996.
- GONZALEZ, R. C.; WOODS, R. E.. *Processamento Digital de Imagens*. Edgard Blücher, 2000. 717p.
- GOODCHILD, M. F.; SHI, W.; FISHER, P. F.. *Spatial Data Quality*. Taylor & Francis, London e New York, 2002.
- GOUVEIA, A. L.; QUEIROZ, C. J. *Aplicação de Técnicas de Sensoriamento Remoto na Análise de Áreas Verdes de Presidente Prudente*. 1999. Trabalho de conclusão de curso (Graduação em Engenharia Cartográfica), Universidade Estadual Paulista - UNESP, Presidente Prudente, SP, 1999.
- HAMBURGER, D. S.. *Utilização de Informações Derivadas de Características Texturais de Imagens Orbitais na definição de Classes de Uso do Solo Urbano*. Apostila. São José dos Campos. INPE, 1993.
- INPE – Instituto Nacional de Pesquisas Espaciais. *Catálogo de Imagens CBERS*. Disponível em: <[www.dpi.inpe.br/catalogo](http://www.dpi.inpe.br/catalogo)>. Acesso em: 2004.
- LIPPMANN, R. P.. An introduction to computing with neural nets. *IEEE ASSP Magazine*, v.4, 4-22p, 1987.
- MACHEACHREN. Visualization Quality and the Representation of Uncertainty. In: \_\_\_\_\_. “Some Truth with Maps”, 1992. p. 67.
- RICHARDS, J. A.; JIA, X.. *Remote Sensing Digital Image Analysis*. Springer, 1999.
- SCHALKOFF, F. *Pattern Recognition: Statistical, Structural and Neural Approaches*. Singapore: John Wiley & Sons, 1992.
- SHIMABUKURO, Y.E.; SMITH, J.A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. *IEEE Transactions on Geoscience and Remote Sensing*, v.29, n.1, p.16-20, 1991.

- VAN DER WEL, F. J. M., VAN DER GAAG, L. C., and GORTE, B. G. H. Visual exploration of uncertainty in remote sensing classification. *Computers and Geosciences*, 24:335-343, 1998.
- VENTURIERI, A.; SANTOS, J. R. Técnicas de Classificação de Imagens para Análise de Cobertura Vegetal. In: ASSAD, E. D.; SANO, E. E., eds. *Sistema de Informação Geográfica: Aplicações na Agricultura*. Brasília: DF. Embrapa – SPI/Embrapa-CPAC, 1998. p 351-371.
- ZELL, A. et al.. *SNNS: Stuttgart Neural Network Simulator*. User Manual, Version 4.1. Stuttgart: University of Stuttgart, 1995.

(Recebido em novembro de 2006. Aceito em maio de 2007)